

논문 2004-41SP-5-15

# 공간 주파수 특성을 가지는 다중 신경 회로망을 이용한 영상 보간

(Image Interpolation Using Multiple Neural Networks with Spatial Frequency Characteristic)

우 동 현\*, 엄 일 규\*\*, 김 유 신\*\*\*

(Dong Hun Woo, Il Kyu Eom, and Yoo Shin Kim)

## 요 약

영상 보간은 기존에 존재하는 화소의 정보로 빈 화소를 계산하여 영상을 확대하는 방법이다. 자연 영상은 다양한 공간 주파수 성분을 포함하기 때문에 하나의 영상 보간 방법으로 다양한 주파수 성분에 대한 보간을 모두 수행하기에는 어려운 점이 있다. 본 논문에서는 공간 주파수 특성을 가지는 다중 신경회로망 구조를 이용하여 영상을 보간하는 방법은 제안한다. 입력 영상은 국부 분산에 의해 공간 주파수에 따라 분리되어 공간 주파수 대역 별로 설정된 신경회로망을 통하여 보간 된다. 제안 방법은 deinterlacing에서의 적용성 때문에 관심이 커지고 있는 2배의 영상 보간에 적용되었다. 모의 실험에서 제안 방법은 기존의 알고리즘들뿐 아니라 단일 신경 회로망을 사용하는 방법보다 개선된 PSNR 성능을 보여주었다.

## Abstract

Image interpolation is an image enlargement method that calculates an empty pixel value using the information of given pixel values. Since a natural image is composed of various spatial frequency components, it is difficult for one method to interpolate pixels with various spatial frequencies. In this paper, we propose an image interpolation method using multiple neural networks with spatial frequency characteristic. Input image is segmented according to spatial frequency by local variance, and each segmented image is interpolated using neural network established for spatial frequency band. The proposed method is applied to line doubling that becomes an important part in image interpolation because of deinterlacing. In simulation the proposed algorithm shows the improved PSNR result compared with conventional algorithms and method using single neural network.

**Keywords:** 공간 주파수, 다중 신경 회로망, 영상 보간, Deinterlacing

## I. 서 론

최근 HDTV와 같은 고화질 디스플레이 장치와 캠코

더, 디지털 카메라 같은 디지털 영상 획득 매체의 급속한 보급으로 주어진 입력 영상을 원하는 크기로 확대하는 응용분야에 대한 중요성이 계속 커지고 있다. 또한 SDTV의 비월주사 방식의 영상을 순차주사 방식의 영상으로 변환하는 deinterlacing, 여러 장의 저해상도 영상으로부터 고해상도 영상을 획득하는 superresolution 등도 영상 확대의 중요한 적용 분야들이다. 이러한 분야들은 기존에 존재하는 화소의 정보로 빈 화소를 계산하는 영상 보간으로 볼 수 있다.

영상 보간을 디지털 신호처리의 관점에서 보면 다음과 같다. 입력 영상은 고해상도 영상이 디지털 영상 획득 매체를 통과하면서 저대역 통과 필터를 통과한 후 다

\* 정회원, 부산대학교 전자공학과  
(Dept. of Electronic Engineering, Pusan National University)

\*\* 정회원, 밀양대학교 정보통신공학과  
(Dept. of Information and Communication, Miryang National University)

\*\*\* 정회원, 부산대학교 컴퓨터 및 정보통신 연구소  
(Research Institute of Computer and Information and Communication, Pusan National University)  
접수일자: 2003년11월21일, 수정완료일: 2004년9월7일

은 샘플링된 것으로 볼 수 있다. 일반적으로 자연 영상의 공간 주파수 성분은 저 주파수 영역에 걸쳐 존재하므로 다운 샘플링 시 위신호(aliasing) 효과로 인한 정보 손실이 발생한다. 위신호 효과로 인한 정보 손실은 주로 고주파 성분에 집중적으로 발생한다. 또한 다운 샘플링에 대응하는 업 샘플링 후 특정한 저대역 통과 필터를 가해주는 bilinear, bicubic 등과 같은 전통적인 보간 방법들은 저대역 통과 특성으로 인해 고주파 대역 부분의 정보손실을 제대로 복원할 수 없으므로 주관적인 측면에서 선명하지 못한 영상이 획득된다<sup>[2]</sup>.

지금까지 연구된 많은 보간 알고리즘들은 이러한 확대된 영상의 에지 부분에서의 흐림(blurring)현상을 개선하는 데 초점을 맞추고 있다. 주로 deinterlacing에 적용되는 ELA(Edge line based algorithm)<sup>[3]</sup>은 보간할 화소의 주위의 기존 화소들의 각 방향별 차이를 계산한 후 가장 작은 차이가 나는 방향의 화소들의 평균으로 보간할 화소값을 결정한다. 이 방법은 간단하고 주관적인 화질측면에서 에지가 매끈하게 보간되는 장점이 있다. 그러나 이 방법은 입력 영상에 저대역 통과 필터를 가한 형태이므로 고주파 성분의 상실을 피할 수 없고 잘못된 에지 방향 선택으로 인한 화질의 열화가 종종 발생한다. 반면에 선형 필터<sup>[6]</sup>는 전통적인 bilinear나 bicubic 방법의 주파수 특성에 비해 고주파 성분을 강조하는 필터 특성을 가지고 있다. 이로 인해 영상의 고주파 영역에서 좋은 PSNR 성능을 보여주고 있지만 대각 방향 에지의 경우에 상당한 블록화 현상들이 발생하며 영상의 평탄 영역에서는 오히려 좋지 않은 성능을 보여준다. Xin Li<sup>[4]</sup>는 입력 영상의 기존 화소들의 관계를 LSE(Least Square Estimation)를 사용해서 추정하여 영상 보간에 적용하였다. 이 방법은 기존 화소들의 관계가 명확한 길고 강한 에지에서 고주파 성분을 효과적으로 복원하였다. 그러나 방향성을 찾기 힘든 복잡한 에지에서 상당한 화질의 열화를 나타내며 계산량의 부담도 크다.

Plaziac은 신경회로망을 이용한 영상 보간 방법을 제안했다<sup>[1]</sup>. 이 방법은 앞의 방법들과는 달리 신경회로망의 학습 과정에서 고주파 성분의 정보를 이용할 수 있는 장점이 있다. 신경회로망의 학습을 위해 사용되는 대표적인 역전파 알고리즘은 주어진 목표값에 도달하도록 갱신하는 가중치의 값이 음수를 가질 수 있다. 가중치의 음수값은 에지에서 뭉롱화 현상을 야기하는 평균 기반의 기존 알고리즘들과는 달리 고주파 성분을 나타낼 수 있는 샤프닝 작용을 가능하게 한다. 따라서 신경

회로망을 이용한 영상 보간은 영상의 저주파 성분뿐만 아니라 고주파 성분을 효과적으로 복원할 수 있는 장점을 가지고 있다. 그러나 신경회로망은 복잡하고 다양한 패턴을 가진 데이터를 학습할 때는 국부 최소값에 빠지기 쉽다. 영상의 경우를 예로 들면, 영상에서는 에지 영역과 평탄 영역의 주파수 특성이 다르므로 하나의 신경회로망은 상당히 다른 특성을 가지는 두 데이터를 학습해야 되는 부담이 따른다. 따라서 유사한 데이터만을 학습하는 경우에 비해 보간의 성능이 떨어지게 된다. 학습 데이터의 크기가 크고 다양성이 큰 데이터의 경우는 더욱 성능이 떨어질 수 있다고 본다.

본 논문에서는 입력 영상을 국부 분산을 이용하여 분할하고, 분할된 영상에 대하여 공간 주파수 특성을 가지는 다중 신경회로망 구조를 이용하여 영상을 보간하는 방법은 제안한다. 제안 방법은 영상을 주파수 대역으로 분할하여 영상의 공간 주파수 대역을 한정하고, 이에 대하여 서로 독립된 신경회로망의 학습을 통한 영상 보간을 수행하는 방법이다. 즉, 데이터의 복잡도를 줄이고 화소가 가질 수 있는 편차를 제한함으로써 학습의 효과를 높일 수 있는 장점이 있다. 또한 전 공간 주파수 대역을 가지는 단일 신경회로망 구조보다 고주파 성분을 잘 모델링할 수 있다. 모의 실험에서 제안방법은 deinterlacing과 밀접한 관련이 있는 영상의 2배 확대에 적용되었다. PSNR 측면에서 제안방법은 기존 알고리즘들에 비해 개선된 성능을 보여주었다.

본 논문은 다음과 같은 순서로 구성된다. 먼저 II장에서 신경회로망을 이용한 영상 보간을 소개하고 III장에서는 제안 알고리즘을 보여준다. IV장에서 모의실험 결과를 보여주며 V장에서 결론을 맺는다.

## II. 신경 회로망을 이용한 영상 보간

신경회로망은 인간의 두뇌 활동을 모델링한 문제 해결 방법으로 패턴 인식, 함수 추정, 신호 처리 등의 여러 분야에서 좋은 성능을 보여 주고 있다<sup>[7-8]</sup>. 그림 1은 가장 널리 쓰이는 다층 퍼셉트론(Multi-Layer Perceptron : MLP) 신경회로망의 일반적인 구조를 보여준다. 그림 1의 신경회로망의 입출력 관계는 다음과 같다.

$$y = \Gamma[W\Gamma[Vx]] \quad (1)$$

여기서  $x$ 는 크기  $n$ 을 가지는 입력 벡터를 나타내고  $y$ 는 크기  $m$ 을 가지는 출력 벡터를 나타낸다.  $w, v$ 는




그림 1. 다층 퍼셉트론 신경 회로망의 구조.  
Fig. 1. The structure of MLP neural network.

각각  $m \times h$  출력층 가중치 행렬 및  $h \times n$  은닉층 가중치 행렬이며,  $h$ 는 은닉층의 개수이다.  $\Gamma[\cdot]$ 은 활성화 함수(activation function) 행렬이며 다음과 같은 형태를 가진다.

$$\Gamma[\cdot] = \begin{pmatrix} f(\cdot) & 0 & \dots & 0 \\ 0 & f(\cdot) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & f(\cdot) \end{pmatrix} \quad (2)$$

활성화 함수  $f(\cdot)$  는 비선형 함수로써 일반적으로 다음과 같은 sigmoid 함수가 많이 사용된다. 즉,

$$f(x) = \frac{1}{1 + \exp(-\lambda x)} \quad (3)$$

앞의 식에서 볼 때, 신경회로망은  $\mathbf{W}, \mathbf{V}$ 를 필터 계수를 가지는 선형 필터에 비선형성이 가미된 것으로 볼 수 있다. 신경회로망의 가중치 행렬  $\mathbf{W}, \mathbf{V}$ 은 gradient descent 알고리즘에 의해 갱신되며, 가중치의 갱신은 다음과 같이 수행된다.

$$\Delta w_{kj} = -\eta \frac{\sigma E}{\sigma w_{kj}}, \quad \Delta v_{ji} = -\eta \frac{\sigma E}{\sigma w_{ji}} \quad (4)$$

여기서  $\Delta w_{kj}$ 는 출력층의 가중치  $w_{kj}$ 의 변화량이며  $\Delta v_{ji}$ 는 은닉층의 가중치  $v_{ji}$ 의 변화량이고,  $i = 1, \dots, n, j = 1, \dots, h, k = 1, \dots, m$  이다. 또한  $E$ 는 입력 벡터에 대한 오차를 나타낸다. 식(4)에서 보는 바와 같이 가중치는 입력 벡터의 에러를 감소시키는 방향으로 변화한다<sup>[5]</sup>.

신경회로망을 이용한 문제 해결에서는 신경회로망의 입력과 출력 관계를 설정하는 것이 중요하다. 신경회로망의 입출력 관계는 응용분야에 따라 다양하게 설정될 수 있으며, 영상을 보간하기 위해서도 적절하게 설정되어야 한다. Plaziac은 다층 퍼셉트론을 이용한 영상 보




그림 2. 영상 보간을 위한 신경 회로망의 입출력 구조.  
Fig. 2. The input-output structure of neural network for image interpolation.

간 방법을 제안하였다<sup>[1]</sup>. 그림 2는 Plaziac에 의해 제안된 2배 영상 확대에 적용된 신경 회로망의 입출력의 구조를 보여준다. 그림 2에서 'X'는 신경 회로망의 출력이고 음영으로 표시된 부분은 입력이다. 즉, 주어진 30개의 화소를 이용하여 3개의 화소를 보간하는 구조로써 신경회로망의 가중치들이 식(4)와 같이 오차를 감소시키는 방향으로 갱신되도록 학습을 하게 된다.

신경회로망의 학습 과정에서 가중치  $\mathbf{W}, \mathbf{V}$ 는 음의 값도 가질 수 있다. 이것은 양의 값만을 계수로 가지는 bilinear, bicubic 방법 및 ELA 같은 기존의 대표적인 보간 알고리즘들과의 중요한 차이점이 된다. 즉, 신경회로망은 어떤 경우에는 음의 계수값에 의해 일종의 고주파 필터의 역할을 할 수도 있으며 다른 경우에는 저대역 통과 필터의 역할을 할 수도 있다. 이는 기대 출력값이 어떤 값을 가지느냐 따라 결정된다. 결국 신경회로망은 입력의 형태에 적응적으로 반응하므로 다양한 형태의 화소 분포를 보간해야 하는 영상 보간에서 효과적이라는 것을 알 수 있다.

단일 신경회로망 구조에서 가중치의 변화는 하나의 입력 벡터에 대해서 수행되기 때문에, 다양한 입력 패턴을 가지는 영상의 경우에는 하나의 패턴에 대한 오차의 감소가 다른 패턴에 대해서는 오차의 증가를 뜻할 수 있다. 또한 많은 입력 벡터에 의해 오차 공간이 복잡해지므로 학습 과정에서 학습이 어려워지고 국부 최소값(local minimum)에 빠질 가능성도 커지게 된다.

### III. 제안 방법

#### 3.1 공간 주파수 특성을 가지는 다층 신경 회로망

본 논문에서는 신경회로망의 복잡한 학습 데이터에 대한 학습의 어려움을 해결하고 신경회로망의 성능을




그림 3. 제안된 다중 신경회로망 구조  
Fig. 3. The proposed structure of multiple neural networks.

향상시키기 위해 공간 주파수에 따라 독립적인 신경회로망 구조를 사용하는 방법을 제안한다. 하나의 보간할 화소 주위의 신경 회로망의 입력 벡터  $\mathbf{x}$ 는 국부 분산 의해서 두개의 영역  $\mathbf{R}_1$  과  $\mathbf{R}_2$ 로 분리될 수 있다. 즉, 해당 화소의 국부 분산  $\mathbf{F}(\mathbf{x})$ 에 의해 다음과 같이 분리된다.

$$\begin{cases} \mathbf{x} \in \mathbf{R}_1 & \text{if } \mathbf{F}(\mathbf{x}) \geq \mathbf{T} \\ \mathbf{x} \in \mathbf{R}_2 & \text{if } \mathbf{F}(\mathbf{x}) < \mathbf{T} \end{cases} \quad (5)$$

여기서  $\mathbf{T}$ 는 문턱값을 나타내며,  $\mathbf{F}(\mathbf{x})$ 는 다음과 같다.

$$\mathbf{F}(\mathbf{x}) = \frac{1}{n} \sum_{m=1}^n (x_m - \mu)^2 \quad (6)$$

식 (6)에서  $\mu$ 는 벡터  $\mathbf{x}$ 의 성분의 평균값이다. 식 (5)에 의해 신경 회로망의 입력 영상 벡터  $\mathbf{x}$ 는 주파수 특성에 따라서 영역  $\mathbf{R}_1$ 에 속하는  $\mathbf{x}^1$  또는 영역  $\mathbf{R}_2$ 에 속하는  $\mathbf{x}^2$ 로 분류되며, 분류된 영상에 대하여 각각의 다층 퍼셉트론 신경회로망을 사용한다. 각각의 영상에 대해 독립적인 다층 퍼셉트론이 적용될 때, 신경회로망 학습은 다음과 같다.

$$\Delta w_{kj}^c = -\mu \frac{\sigma E^c}{\sigma w_{kj}^c}, \quad \Delta v_j^c = -\mu \frac{\sigma E^c}{\sigma v_j^c}, \quad c = 1, 2 \quad (7)$$

그림 3은 제안된 다중 신경회로망의 구조를 나타낸다. 같은 영역의 입력 패턴들은 유사한 주파수 특성을 가지고 있으므로 한 패턴에 대한 에러의 감소가 다른 패턴의 에러의 증가를 초래하는 현상을 줄일 수 있다. 따라서 보다 정확한 학습이 가능하다. 또한 본 논문에서는 Plaziac이 제안한 신경회로망의 입출력 관계<sup>[1]</sup> 대신 그림 4와 같은 입출력 구조를 제안한다. 본 논문의 방법은 20개의 화소 입력에 대하여 하나의 출력을 가지는 구조를 가진다.




그림 4. 제안된 신경회로망의 입출력 구조.  
Fig. 4. The proposed input-output structure of neural network.

### 3.2 신경 회로망의 AC-DC 모듈화

제안된 다중 신경회로망 구조에 의해 독립적으로 학습되는 영상 데이터들 사이에도 다양한 패턴이 존재한다. 예를 들어, 고주파 영역에 해당하는  $\mathbf{R}_1$ 에 속하는 영상의 경우 강한 에지, 텍스처(texture), 복잡한 에지 등의 다양한 형태가 존재하며 에지의 강도도 각각이다. 영상 데이터의 다양성은 앞에서 언급한 것처럼 신경회로망의 정확한 학습을 교란시키는 요인이 된다. 따라서 본 논문에서는 입력 영상의 패턴의 다양성으로 인한 학습의 교란을 줄이면서 또한 신경회로망의 다양한 패턴에 대한 적응성을 유지하기 위해 모듈화 된 신경회로망이 제안한다.

본 논문에서는 각 영역에 대해 동일한 구조의 모듈화된 신경 회로망이 적용된다. 설명을 위해 영역  $\mathbf{R}_1$ 의 경우를 생각한다. 영역  $\mathbf{R}_1$ 의 입력 벡터  $\mathbf{x}^1$ 의 AC 성분  $\mathbf{x}^{1,AC}$ 와 DC 성분  $\mathbf{x}^{1,DC}$ 를 추출하여 그림 5와 같은 모듈화 된 구조의 신경회로망에 입력한다.  $\mathbf{x}^{1,AC}$ 는 다음과 같이 결정한다.

$$\mathbf{x}^{1,AC} = [x_1^1 - \mu_{x_1^1}, x_2^1 - \mu_{x_2^1}, \dots, x_n^1 - \mu_{x_n^1}] \quad (8)$$

식 (8)에서  $\mu_{x_i^1}$ 은 입력 벡터  $\mathbf{x}^1$ 의 성분들의 평균값이다.  $\mathbf{x}^{1,DC}$ 는 그림 5의 9개의 영역  $\mathbf{g}_m$  ( $m = 1, 2, 3, \dots, 9$ )의 평균값들로 구성된다. 즉,

$$\mathbf{x} = [\mathbf{A}_1^1, \mathbf{A}_2^1, \dots, \mathbf{A}_9^1] \quad (9)$$

여기서  $\mathbf{A}_m^1$ 은 각 영역 화소값의 평균을 나타낸다. 따라서 제안 신경회로망의 전체적인 입출력 관계는 다음과 같다.

$$\mathbf{y}^c = \Gamma[\mathbf{w}^{c,AC} \Gamma[\mathbf{v}^{c,AC} \mathbf{x}^{c,AC}] + \mathbf{w}^{c,DC} \Gamma[\mathbf{v}^{c,DC} \mathbf{x}^{c,DC}]] \quad (10)$$

,  $c = 1, 2$




그림 5. 제안된 모듈화 된 신경 회로망.  
Fig. 5. The proposed modularized neural network.

식 (10)에서 보여진 것처럼 각 모듈은 출력층에서 합쳐져서 최종 출력을 형성하게 된다. 이 경우 각 모듈의 가중치 갱신은 다음과 같다.

$$\Delta w_{kj}^{c,AC} = -\mu \frac{\sigma E^c}{\sigma w_{kj}^{c,AC}}, \quad \Delta v_{kj}^{c,AC} = -\mu \frac{\sigma E^c}{\sigma v_{kj}^{c,AC}} \quad (11)$$

$$\Delta w_{kj}^{c,DC} = -\mu \frac{\sigma E^c}{\sigma w_{kj}^{c,DC}}, \quad \Delta v_{kj}^{c,DC} = -\mu \frac{\sigma E^c}{\sigma v_{kj}^{c,DC}} \quad (12)$$

주어진 입력에 대해서 각 모듈의 가중치들은 두 개의 모듈의 출력의 합과 기대 출력과의 오차를 감소시키는 방향으로 가중치를 조절하게 된다. 각 모듈은 자신의 입력에 대해 전체 오차를 감소시키는 방향으로 동작하므로, AC 모듈에서의 오차 감소가 적은 영상에 대해서 DC 모듈에서 오차를 크게 감소시킬 수 있고 그 반대의 경우도 가능하다. 즉, 두 개의 모듈이 상호 보완적으로 작동한다. 이러한 구조를 통해서 제안된 신경회로망은 단순히 입력으로 기존 화소의 밝기값을 갖는 경우에 비해 효율적으로 작동한다.

그림 6은 제안 신경회로망의 전체적인 개념을 보여준다. 그림 6에서 보간할 화소의 주변 화소들은 해당 영역의 모듈화 된 신경회로망의 입력으로 들어간다. 신경회로망은 보간할 화소의 밝기값을 출력으로 낸다.




그림 6. 영상 보간을 위한 제안 신경 회로망의 전체 구조.  
Fig. 6. Overall structure of the proposed neural network for image interpolation.

#### IV. 모의 실험 결과

본 논문에서는 제안된 알고리즘의 성능을 평가하기 위해서 영상 보간 방법 중에서 ELA 방법, 선형 필터를 이용한 방법, 메디안 필터를 이용한 방법, 단일 신경회로망을 이용한 방법과의 PSNR을 비교하였다. 신경회로망의 학습을 위해서 tiffany, truck, tank, airplane, aerial, zelda, couple, mandrill, elaine, goldhill, crowd, bridge의 12개의 512\*512 영상이 사용되었으며, 검증용 위해서는 lena, boat, peppers, barbara의 4개의 영상이 사용되었다. 표 1은 제안 방법과 다른 영상 보간 방법들의 PSNR 결과를 보여준다. 표 1에서 단일 신경회로망은 입력으로 그림 4의 입력 구조를 사용한 방법이다. 이 구조는 Plaziac의 방법<sup>[1]</sup>보다 간단한 구조를 가지고 있음에도 불구하고 동등한 성능을 보여준다. 또한 표에서 제안방법(1)은 제안된 다중 신경 회로망 방법에서 각 영역에 대해 다중 퍼셉트론 신경 회로망을 사용한 경우이고 제안방법(2)는 각 영역에 대해 제안된 모듈화 된 신경 회로망이 사용된 경우이다. 표에서 보는 바와 같이 단일 신경 회로망을 사용했을 때보다 다중 신경 회로망 방법을 사용했을 때 작게는 0.1dB에서 크게는 1dB 정도의 성능 개선을 보여준다. 또한 다중 신경 회로망 방법에서 제안된 모듈화 된 신경회로망을 사용했을 때 추가적인 성능 개선이 있음을 볼 수 있으며, 특히 텍스처 부분이 많은 barbara영상에서 성능 개선의 폭이 크다. 따라서 제안된 모듈화 된 신경회로망이 다중 퍼셉트론 신경 회로망의 경우보다 영상의 다양한 형태에 보다 잘 적응함을 알 수 있다.

그림 7과 그림 8은 제안 방법과 다른 방법들과의 주관적 화질 비교이다. 그림 7은 lena 영상에 대해 선형 필터를 이용한 방법을 적용했을 때와 제안 방법을 적용

표 1. 제안 알고리즘과 다른 알고리즘들 사이의 PSNR 비교  
Table 1. The PSNR comparison between the proposed and other algorithms.


	ELA	Linear	Median	Single NN	제안 방법(1)	제안 방법(2)
Lena	33.59	38.03	36.78	38.28	38.55	38.64
Boat	30.70	36.88	33.45	36.77	36.86	37.02
Peppers	33.75	33.51	32.73	35.60	36.09	36.12
Barbara	24.04	33.44	27.93	32.22	33.20	33.51



(a) (b)

그림 7. 선형 필터를 이용한 방법과 제안 알고리즘 사이의 주관적 화질비교 (a) 선형 필터를 이용한 방법(38.03dB) (b) 제안 알고리즘(38.64)

Fig. 7. The subjective quality comparison between method using linear filter and proposed algorithm (a) method using linear filter(38.03dB) (b) proposed algorithm(38.64dB).



(a) (b)

그림 8. ELA 방법과 제안 알고리즘 사이의 주관적 화질비교 (a) ELA 방법(24.04dB) (b) 제안 알고리즘(33.51dB)

Fig. 8. The subjective quality comparison between ELA method and proposed algorithm (a) ELA method(24.04dB) (b) proposed algorithm(33.51dB).

했을 때의 비교이다. 그림에서 보는 바와 같이 선형 필터는 모자챙 부근에서 블록화 현상을 일으키는 데 비해 제안 방법은 비교적 매끄럽게 보간하는 것을 볼 수 있다. 한편 그림 8은 barbara 영상에 대해 ELA 방법과 제안 방법의 비교이다. 그림에서 ELA 방법은 영상의 텍스처 부분에서 에지의 방향을 잘못 찾음으로 인해서

상당한 화질의 열화를 보여주고 있다. 반면에 제안 방법은 그런 부분을 잘 보간하는 것을 볼 수 있다.

### V. 결 론

본 논문에서는 공간 주파수 특성을 가지는 다중 신경 회로망을 이용한 영상 보간 방법을 제안하였다. 제안 방법에서는 먼저 공간 주파수 측면에서 크게 다른 성질을 가지는 두 개의 영역(에지 영역과 평탄 영역)을 분리하였다. 또한 각 영역 안에서의 다양한 변화에 효과적으로 반응하기 위해 입력 영상의 AC 성분과 DC 성분으로 모듈화 된 신경회로망을 제안하였다. 모의 실험에서 제안 방법은 다른 방법들에 비해 개선된 객관적 성능을 보여주었고 주관적인 면에서도 좋은 화질을 보여주었다.

### 참 고 문 헌


- [1] Nathalie Plazaic, "Image interpolation using neural networks," IEEE Trans. Image Processing, Vol. 8, No. 11, pp. 1647-1651, Nov. 1999.
- [2] A. V. Oppenheim, and R.W. Schaffer, Discrete-time Signal Processing, Prentice Hall, pp. 102-111, 1989.
- [3] G. D. Haan, and E. B. Bellers, "Deinterlacing an Overview," In Proc. IEEE, Vol. 86, No. 9, pp. 1839-1857, Sep. 1998.
- [4] X. Li, and M. Orchard, "New Edge-directed interpolation," IEEE Trans. Image Processing, Vol.10, No.10, pp.1521-1527, 2001.
- [5] J. M. Zurada, Introduction to Artificial Neural System, PWS Publishing Co., pp.163-250, 1995.
- [6] ISO/IEC/JTC1/WG11/MPEG93/143, Rome, Italy, Jan. 1993.
- [7] S. W. Lee, "Off-line recognition of totally unconstrained handwritten numerals using multilayer cluster neural network," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 18, No. 6, pp.648-652, June 1996.
- [8] Dong-Hun Woo, Charm-Han Ko, Hyun-Min Kang, Yoo-Shin Kim, Hyung-Soon Kim, "Narrowband to Wideband Conversion of Speech Using Modularized Neural Network," 7th International Symposium Artificial Life and Robotics, Vol.2, pp.622-625, Beppu, Japan, Jan. 2002.

저 자 소 개



우 동 현(정회원)  
 1998년 부산대학교 전자공학과  
 학사.  
 2000년 부산대학교 전자공학과  
 석사.  
 2000년~현재 부산대학교 전자공  
 학과 박사 과정.

<주관심분야: 영상처리, 패턴인식, 웨이블릿 변환  
 신호처리, 신경회로망>



김 유 신(정회원)  
 1974년 서울대학교 전자공학과  
 학사.  
 1980년 U.C. Berkeley 전자공학과  
 석사.  
 1983년 Standford University  
 전자재료 박사과정 수학.

1995년 Cornell University Ph.D  
 1983년~현재 부산대학교 전자공학과 교수  
 현재 한국 과학철학회 회장  
 <주관심분야: 영상처리, 신경회로망, 공학윤리, 과  
 학기술철학>



엄 일 규(정회원)  
 1990년 부산대학교 전자공학과  
 학사.  
 1992년 부산대학교 전자공학과  
 석사.  
 1998년 부산대학교 전자공학과  
 박사.

1997년~현재 밀양대학교 정보통신학과 부교수  
 <주관심분야: 통계신호처리, 영상처리, 웨이블릿  
 변환 신호처리, 신경회로망>